

**Tihana Škrinjar**  
 Sveučilište u Zagrebu  
 Ekonomski fakultet Zagreb  
 Trg J. F. Kennedyja 6,  
 10000 Zagreb, Hrvatska  
[tskrinjar@net.efzg.hr](mailto:tskrinjar@net.efzg.hr)  
 Tel: +3851238 3325

# PRIKAZ KNJIGE „NONLINEAR TIME SERIES ANALYSIS“

NASLOV: Nonlinear time series analysis

AUTORI: **Ruey S. Tsay, Rong Chen**

IZDAVAČ: John Wiley & Sons Inc., Hoboken.

GODINA IZDAVANJA: 2018

Broj stranica: 496

ISBN: 978-1119264057

Učenje i primjena ekonometrije u ekonomiji započinje linearnim modelima, s obzirom na njihovu jednostavnost i interpretabilnost. Međutim, već je dugi niz godina u primjeni ekonometrijskih metoda i modela prepoznat značaj nelinearnosti u vezama (ne samo ekonomskih) varijabli i njihovom ponašanju. Iz tog razloga, sve je više literature koja izučava nelinearne modele i metode za opisivanje stvarnog ponašanja. Tako knjiga *Nonlinear time series analysis* pripada u skupinu literature koja se bavi uvodom u nelinearne modele. Sastoji se od ukupno 8 poglavlja, s mnoštvom primjera provedenih u programskoj podršci R, pri čemu autori na određenim mjestima u knjizi daju i popis naredbi potrebnih da bi određeni primjer čitatelj sam proveo u R, jer su podaci korišteni u knjizi dostupni na službenoj mrežnoj stranici knjige. Za tečno čitanje knjige i praćenje materije u njoj, čitateljima se preporučuje osnovno do solidno znanje iz ekonometrije koje uključuje univarijatne i multivarijatne modele vremenskih serija.

Prvo poglavlje prikladnog je naziva: *Zašto bismo marili o nelinearnosti?* U njemu autori daju motivaciju za izučavanjem ovakve materije. Kratko se uvode osnovni pojmovi vezani uz vremenske serije (stacionarnost, korelogrami i slično) te se daju

primjeri tipičnih nelinearnih modela primjenjivih u ekonomiji. Na kraju poglavlja obrađuju se testovi nelinearnosti vremenskih serija, poput neparametrijskih: Portmanteau testa ranga (engl. *Rank-based Portmanteau test*), McLeod–Li testa, Brock et al. (1987) testa, ali i parametrijskih (RESET, F i *threshold* testovi). Drugo poglavlje bavi se univarijatnim parametrijskim nelinearnim modelima pa su ovdje uključeni TAR (engl. *threshold autoregression*), MSM (engl. *Markov switching model*), STAR (engl. *smooth transition autoregression*) te modeli s vremenski-promjenjivim parametrima (engl. *time varying coefficients models*). Navode se svojstva pojedinih modela, metode procjene, prognoziranje i za svaki model prikazuju se primjeri, posebno s grafičkim prikazima, kako bi čitatelji lakše savladali materiju.

Može se uočiti da su dane detaljne interpretacije u primjerima, što mnogima može biti važno kako bi lakše povezali teoriju s primjenama. S druge strane, dovoljno je teorije predočeno da se može s razumijevanjem naučiti, primjerice iterativna metoda procjene parametara u modelu promjene režima. U ovome poglavlju je dosta pozornosti posvećeno metodima najveće vjerodostojnosti, s obzirom da se brojni modeli procjenjuju upravo pomoću ove metode. Primjeri se protežu kroz veći broj stranica.

Drugo poglavlje predstavlja temelj koji je potrebno savladati prije prelaska na ostatak knjige.

Neparametrijski univarijatni modeli razmatraju se u trećem poglavlju, kako bi se povećala fleksibilnost modeliranja. Ovdje se obrađuju izgladivanje kernela (engl. *kernel smoothing*) uz različite stupnjeve izgladivanja; procjenjivanje splineova (engl. *splines*) gdje se razmatraju različiti funkcionalni oblici za

pojedini dio tih krivulja s obzirom na stvarne podatke. Potom se obrađuju krivulje izgladivanja (engl. *smoothing splines*) kao i *walvelet* izgladivanje koje je korisno za vremenske serije s velikim oscilacijama tijekom vremena. Posljednji dio poglavlja bavi se nelinearnim aditivnim modelima. Može se uočiti da su autori svjesni da određeni modeli nisu toliko popularizirani u primjenama, stoga se više pojašnjenja posvećuje njima i opisu postupka kako ih procijeniti i analizirati, pa tako i u ovome poglavlju.

Za one istraživače i čitatelje koji se bave podacima visoke frekvencije, sastavljeno je četvrto poglavlje, naziva *Neuronske mreže, duboko učenje i metode grananja* (engl. *neural networks, deep learning and tree-based methods*). Poglavlje započinje neuronskim mrežama, opisom postavljanja osnovnih modela i metodama procjene. U empirijskom primjeru uočava se da je potrebno imati znanja iz univarijantnih modela vremenskih serija (ARMA modeli i slično), što je već spomenuto na početku. Duboko učenje nastavlja se na neuronske mreže i koristi se veoma recentna literatura na koju se zainteresirani čitatelji mogu dalje uputiti. Kako se spomenute metode često koriste u svrhu prognoziranja, primjeri su najviše usmjereni upravo na to. Isto vrijedi i za metode grananja (gdje se obrađuju regresijski modeli grananja, kao i klasifikacijski modeli; engl. *regression trees and classification trees*). Većina primjera je vezana uz dionice i vremenske serije prinosa, zbog količine podataka koji su dostupni za ovakve analize.

Zbog problema narušavanja nenormalnosti distribucije (slučajne) varijable, autori razmatraju u petome poglavlju analizu vremenskih serija koje nisu normalno distribuirane: GARMA, GLM, GLARMA, M-GARMA (engl. *generalized ARMA, generalized linear models, generalized linear ARMA, martingalized ARMA*); te funkcionalne vremenske serije (engl. *functional time series*). Ovi modeli korisni su za financijske primjene, te se povezuju u ostatku poglavlja s GARCH (engl. *generalized autoregressive conditional heteroskedasticity*) modelima kao tipičnima u financijskim primjenama. Posljednjih nekoliko godina u primjenama su sve popularniji *state space* modeli, stoga se obrađuju u šestome poglavlju, a dodatno i nelinearni *state space* modeli u sedmome. Ovakvi modeli prikladni su u slučaju kada podaci u sebi sadrže tzv. buku (engl. *noisy data*). Poglavlje na strukturiran način predočava uvod u *state space* modele i logi-

ku razmišljanja kod ovakvog modeliranja. ARMA model se predočava na ovaj način, kao i model s vremenski promjenjivim parametrima te dinamički faktorski model (engl. DFM – *dynamic factors model*) i modeli s promjenom režima, jer su upravo ovo sve češće primjenjivani modeli u empirijskim istraživanjima. Naravno, obrađuje se i Kalmanov filter.

Dodatan značaj u ovome poglavlju nalazi se u opsežnom popisu literature koja je nastala u posljednjih desetak godina, s obzirom na veliku primjenjivost ovog pristupa u modeliranju; kao i u primjerima koji se protežu na više od 30 stranica. Nelinearni *state space* modeli u sedmome poglavlju su nastavak prethodnoga te se ne preporučuje preskakati šesto poglavlje s obzirom da se oznake, modeli i koncepti u sedmome nadograđuju na prethodnu materiju. Tako se, primjerice, odmah započinje proširenim Kalmanovim filtrom. I u ovome poglavlju teorija je nešto opširnija, s obzirom na svjesnost autora da se određeni pojmovi i modeli tek razvijaju pa nisu široko još popularizirani u knjigama. Ovo se može smatrati još jednom od dodatnih prednosti ove knjige u odnosu na postojeću literaturu.

Posljednje, osmo poglavlje bavi se *Monte Carlo* simulacijama; točnije, sekvencijalnim *Monte Carlo* simulacijama koje mogu pomoći da bi se određeni prethodno obrađivani modeli procijenili s manjom greškom kad se radi o slučajevima iterativnih metoda bez analitičkog rješenja za nepoznate parametre. Najprije se obrađuju uvodne teme simulacija, te se potom proširuju na neke od prethodno obrađivanih modela (primjerice, iz poglavlja sedam nekoliko modela). Ovdje se radi o vjerojatno najzahtjevnijem poglavlju u smislu poznavanja prethodne materije teorije vjerojatnosti, preporučuje se njegovo solidno poznavanje kao i poznavanje integralnog računa, uzorkovanja i izgradnje inferencije procjenitelja. Ovo je ujedno i najopširnije poglavlje.

Naposljetku, ova knjiga preporučuje se onima koji već imaju određenu razinu znanja iz vremenskih serija i primijenjene ekonometrije kako bi nadogradili znanja o nelinearnim modelima. Za očekivanje je da će ovi modeli postati sve popularniji u budućnosti, stoga čitateljima ova knjiga može biti od iznimnoga značaja kao uvodno štivo u spomenutu materiju. Također može biti korisna studentima diplomskih i poslijediplomskih studija, kao i svim istraživačima koji se bave primijenjenom ekonometrijom u svojim analizama.